

XML e rappresentazione della conoscenza per Semantic Web

Piero A. Bonatti

Dipartimento di Tecnologie dell'Informazione

Università di Milano

La ricchezza del Web

- Miniera di informazioni e servizi
- Purtroppo nè strutturati nè omogenei
 - spesso inaccessibili e/o inutilizzabili
- Di fatto, potenzialità sfruttate minimamente
 - search engines rudimentali - basati su topologia e keywords
 - l'integrazione con XML ha dei limiti
- Idea: migliorare sfruttamento risorse Web rappresentandone il *significato*

Semantic Web

Semantic Web

- Reperimento ed uso delle informazioni sulla base del loro significato
 - migliorando sia precisione che recall
- Reperimento ed uso automatici dei servizi software
 - sulla base di quello che il servizio *fa*
- La macchina deve “capire” i documenti e i servizi, in qualche misura
 - rappresentazione ed uso della conoscenza

Indice del seminario

- Ruolo dei markup languages (XML)
nell'*interoperabilità* di sistemi eterogenei
 - e loro limiti
- Description logics
 - linguaggi di rappresentazione della conoscenza
 - loro rappresentazione in XML
- Service Description Logics

Sistemi distribuiti moderni

- Eterogenei, a tutti i livelli di astrazione e granularità
 - HW (workstations, palmari, cellulari, ...)
 - SW (sistemi informativi, agenti, servizi web, oggetti distribuiti,...)
 - Dati (pagine web, databases, ...)
- Componenti progettate e mantenute indipendentemente

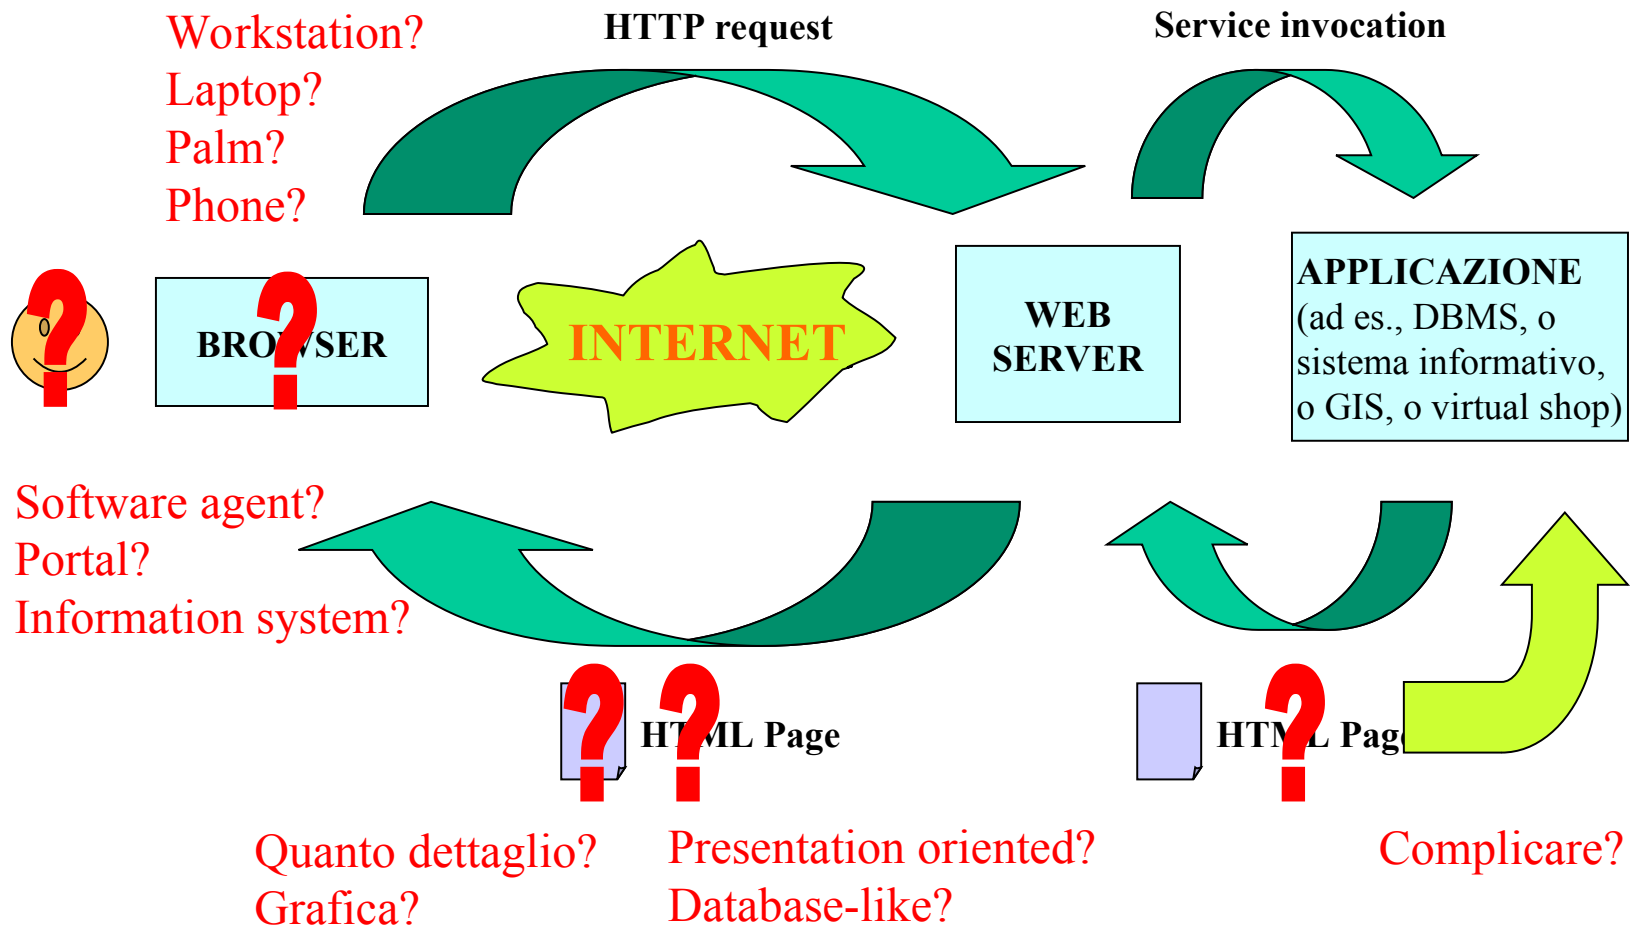
Sistemi distribuiti moderni

- Devono essere **interoperabili** nonostante tutto
 - ogni funzionalità del sistema può richiedere l'interazione di più componenti specializzate
- In ambiente dinamico
 - aggiunta/rimozione/sostituzione componenti
 - non noti a priori
- Cosa si vorrebbe ottenere
 - riconfigurazione spontanea del sistema
 - ...o almeno ridurre i costi degli adattamenti...

Esempio: Web applications

- Tra le caratteristiche importanti:
 - Progettazione dati e documenti senza sapere quali applicazioni li vorranno usare, ne' perche'.
 - Progettazione applicazioni senza sapere con quali altre applicazioni scambieranno dati, ne' come.
- Alcuni esempi
 - web pages & search engines
 - databases & portali
 - servers e clients per e-commerce
 - aste elettroniche & agenti

Esempio 1




Formati e Transazioni




- Un problema particolare riguarda il modo in cui i dati vengono scambiati tra diverse applicazioni
- Potenzialmente ciascuna di esse usa
 - un diverso formato dei dati
 - un diverso protocollo per le transazioni (tipi di messaggi, loro significato, vincoli sulle sequenze)

Esempio 2

- B2B (Business to Business)
 - gestione automatica degli ordini, ...
 - gli adattamenti (a nuovi partners,...) devono seguire la velocità delle relazioni commerciali





Mobile computing



Problema

- Rendere i servizi su Internet accessibili dai terminali mobili
- Questi hanno display molto piccoli e dispositivi di input limitati
- Bisogna adattare la presentazione e le interazioni ai meccanismi di input e output forniti dai diversi tipi di terminali e ai limiti della rete wireless



Strategie x flessibilità

- Disaccoppiare applicazioni da modalità uso
- Separare contenuti da presentazione
 - per facilitare ricollocazione componenti in diversi contesti
- Rappresentazione del *significato* dei dati
 - per reperirli/utilizzarli indipendentemente dal formato scelto da ciascun progettista

Orientato a rappresentazione

Filename: sample.html

<HTML><BODY>

<H1>A Sample Web Page**</H1>**

<H2>Containing a photo of a waterfall...
</H2>

<P>


<P>

HTML consists of **<I>**standardized**</I>**
codes that are used to define the structure of
information that makes up a web page.

<P>

HTML tags are used to place images, create
hypertext links, make text bold, and more!!

</BODY></HTML>



Alcuni tags orientati ai font

- `<B>` e `</B>` sono i tag iniziale e finale per specificare un'area in grassetto (bold)
- `<I>` e `</I>` per il corsivo
- `<em>` e `</em>` per l'emphasized
- `<FONT size=+2>` e `</FONT>` per cambiare dimensione font

Altri tags orientati a struttura

- `<H1> </H1> ... <H6> </H6>` per specificare intestazioni (titoli di documenti, capitoli, sottosezioni) a piu' livelli

- Unordered lists

`<UL>`

`<LI> Abc`

`<LI> Def`

`</UL>`

Effetto:

- Abc
- Def

Da formatting a semantica

- Confrontate:

`<p>P200 laptop`

`<br>Friendly Computer Shop`

`<br>$1438`

con:

`<product>`

`<model>P200 laptop</model>`

`<dealer>Friendly Computer Shop</dealer>`

`<price>$1438</price>`

`</product>`


Documenti o dati?

- I tag possono giocare il ruolo dei nomi delle colonne di una tabella relazionale.
 - Quindi il documento contiene i propri metadati (si *autodescrive*).
- Sfuma la distinzione tra dati e documenti
 - documenti leggibili e visualizzabili
 - ma anche **strutturati e manipolabili automaticamente** (non solo per formatting)

Siamo arrivati a XML...

- Standard di rappresentazione per markup languages
- I tag e il formato possono essere definiti a piacere (DTD, XML Schemas)
- Strumenti per la manipolazione di documenti XML (Parsers, CSS, XSLT, ...)
- Rappresentazioni standard basate su XML (MathXML, WSDL, WIDL, ...)

Punti di disaccoppiamento



XML x database publishing

- Indipendenza database/web site design.
 - un metodo x pagine dinamiche
- Query output in XML, es.:

```
<TOYS>
<ITEM><NAME>GI John</NAME>
      <MANUFACTURER>War Toys Inc.</MANUFACTURER>
      <PRICE>50.95</PRICE>
      <IN-STOCK>3000</IN-STOCK>
<ITEM><NAME>Leggo!</NAME>
      <MANUFACTURER>Grips'R US</MANUFACTURER>
      <PRICE>64.95</PRICE>
      <IN-STOCK>2000</IN-STOCK>
. . . .
</TOYS>
```

Stylesheets x presentazione

- Specifiche dichiarative di trasformazione
- CSS (Cascading Style Sheets) rule-based

selettore elemento proprietà valore


HEAD { display: none }

BODY { display: block }

- XSLT
 - linguaggio funzionale su alberi

Esempio B2B (ripreso)

- schema di interoperabilita' che dovrebbe ridurre la complessita' dei plug-in, sfruttando gli strumenti di parsing e traduzione per XML



XML x e-business

- Es.: elaborazione automatica ordini

```
<TOY-ORDER>
  <Order-No>123456</Order-No>
  <Date>20001002</Date>
  <Customer-No>98765-43</Customer-No>
  <Toy num="13245-23" quantity="12" />
  <Toy num="13425-23" quantity="21" />
  <Toy num="54321-28" quantity="15" />
  . . . .
</TOY-ORDER>
```

- Generati ed inviati automaticamente
- Ricevuti e serviti automaticamente
- Trasformaz. possibilmente rule-based

E-commerce: XML vs EDI

Semplificando:

- EDI: basato su interchange formats mirati a concisione (old technology): niente element names, solo posizionale.
- Tutto da rifare se cambiano formato dati o protocolli transazioni. Formati illeggibili, codice ad-hoc per visualizzazione/estrazione.
- Un'applicazione XML puo' trovare comunque i dati che le servono e ignorare il resto (dati semistrutturati). Transazioni spesso codificabili in singoli documenti.
Rule-based translation

Ruolo dei Markup Languages

- Si propongono come soluzione (parziale) ai problemi di interoperabilita' tra diverse applicazioni, facilitando:
 - **parsing** dei formati e **controlli di correttezza** (in fase di creazione o trasmissione) [**DTD**, **XML-Schemas**, **Parsers**]
 - **trasformazione** da un formato ad un altro [**XSLT**]
 - trasformazione documenti in **strutture dati** direttamente manipolabili da programmi [**DOM**, **SAX**]
 - separazione **formatting** (visualizzazione, stampa, lettura) da contenuto del documento [**XSLT**]

Efficacia dei Markup Languages

- Buona per ridurre i costi dell'adattamento manuale
 - e' facile aggiungere nuovi stili di presentazione ed integrare nuovi sistemi
 - combinando stylesheets per trasformazione e presentazione si specificano concisamente numerose combinazioni predefinite
- Poco per interoperabilita' tra componenti non previsti e riconfigurazioni spontanee
 - multiagent systems, disappearing computing, sfruttamento ricchezza del Web...

Il costo dei tag semantici

- Difficolta` di standardizzazione
 - ciascuno puo` usare tag diversi, es.
<prodotto> invece di <articolo>
- *Difficolta` di ricerca/riconoscimento*
- Domain specific standards
 - possono rivelarsi rigidi / statici
- **Ontologie, rappres. della conoscenza**
 - oggetto di ricerca, difficile ma con forti investimenti

Prospettiva

- Descrizione delle risorse Web basata sul loro **significato (Semantic Web)**
 - linguaggi di rappresentazione della conoscenza derivati da I.A.
 - ontologie x “spiegare” termini alla macchina
- Standard attuali o in corso di sviluppo:
 - **RDF** (Resource Description Format) [W3C]
 - reti semantiche
 - **DAML+OIL** [DARPA, OMG, ...]
 - terminological or description logics/concept languages

Meta informazione in HTML

- Proprieta` del documento, che non appartengono necessariamente al suo contenuto
- `<META name=... content=... >` per specificare proprieta` arbitrarie, come
`<meta name="author" content="bonatti">`
`<meta name="generator" content="mozilla">`
- Semplici associazioni attributo-valore
 - per il valore non e` prevista struttura particolare

Per illustrare RDF

User Agent Profiling

W3C / WAP

Motivazioni

- Rappresentare capacita` di elaborazione e presentazione, nonche` preferenze utente
 - per adattare la presentazione ad HW/SW
 - per filtrare i contenuti rispetto a interessi utente

Linguaggio di rappresentazione

- Standard in evoluzione basati su **RDF** (Resource description framework)
 - un tipo di documenti XML progettato per rappresentare proprietà machine-understandable delle risorse su web
- Standard W3C: CC/PP (Composite Capabilities/Preference Profiles)
- Standard WAP: UAProf (User Agent Profile)


Cenni su RDF

- Elementare linguaggio di K.R.
- Il modello dei dati comprende:
 - risorse, proprieta`, statements (= subject, predicate, object), cioe`relazioni binarie (sufficienti a rappresentare relazioni arbitrarie)
- Esempio:
 - subject = “<http://www.w3.org/Home/Lassila>”
 - predicate = Creator
 - object = “Ora Lassila”

Elementi della sintassi RDF

- RDF: racchiude le descrizioni RDF
- Description: raccoglie il gruppo di statement relativo ad una risorsa

*namespace
dei predicati*



```
...xmlns:s = "some.org/some_schema/"...  
<rdf:RDF>  
<rdf:Description about="subject">  
<s:predicate object </s:predicate>  
</rdf:Description>  
...  
</rdf:RDF>
```


Elementi della sintassi RDF

- Le descrizioni possono usare namespace diversi ed essere innestate

```
<rdf:RDF xmlns:s = "... " xmlns:v = "... " >
<rdf:RDF>
<rdf:Description about="http:www.w3.org/...">
  <s:Creator>
<rdf:Description about="staffID/9835">
<v:Name>Ora Lassila</v:Name>
<v:Email>lassila@w3.org</v:Email>
</rdf:Description>
  </s:Creator>
</rdf:Description>
...
</rdf:RDF>
```

Elementi di RDF


- Esistono abbreviazioni e rappresentazione grafica



Elementi di RDF

- “Containers” per rappresentare collezioni di risorse (Bag, Sequence, Alternative)
 - fanno anche le veci di classi
- Statements about statements (ad esempio chi ha inserito una certa relazione)

Proprieta' client in RDF



Rappresentazioni più complesse

- Restrizioni sui valori degli attributi
 - invece di valori specifici
- Alternative (disgiunzioni)
- Restrizioni numeriche sugli attributi
- **Descrizioni parziali/incomplete**
 - per pattern matching flessibile
 - per descrivere contenuti ambigui
 - ...

Esempio

```
<HTML><HEAD>
```

```
<META name="about" content="semantic_descr">
```

```
...
```

```
</HTML>
```

File semantic_descr:

```
Ontology = "rent_ontology"  
rental and  
    exists object (car and small)  
and  
    exists price;
```

Esempio (cont.)

- Query che sfruttano l'annotazione
 - `rental and exists object (car and big)`
 - `rental and exists object car`
 - `rental and exists object car and exists price`
- Document description $\subseteq$ Query
- Per ottenere il significato desiderato occorre specificare che “big” e “small” sono incompatibili...

Esempio

```
<HTML><HEAD>
```

```
<META name="about" content="semantic_descr">
```

```
...
```

```
</HTML>
```

File semantic_descr:

```
Ontology = "rent_ontology"  
rental and  
    exists object (car and small)  
and  
    exists price;
```

rental, object, car,
small, price e big
sono definiti qui

Ontologie (in informatica)

- Teorie logiche del primo ordine (insiemi di assiomi) che definiscono:
 - *concetti* (simboli di predicato unari)
 - *attributi* (simboli di predicato binari)
- cioè il loro *significato* inteso come l'insieme delle loro proprietà logiche
- Spesso espresse con *linguaggi concettuali*, con inferenza *decidibile* e talora *PTIME*

Ruolo di XML

- Permette di creare i legami tra risorse e loro significato
 - con opportuni attributi ed elementi
- di definire e fare parsing dei linguaggi delle ontologie
 - con RDF ed estensioni
- e (potenzialmente) di creare mapping tra diverse ontologie
 - strumenti di trasformazione (futuribile, limitativo)

DAML+OIL

- DAML = Darpa Agent Markup Language
- OIL = Ontology Inference Layer
- Linguaggio concettuale per la rappresentazione della conoscenza
- Sintassi definita in/con XML
- Vedremo esempi per illustrare espressività del linguaggio

Definizione classi

- Le classi definiscono concetti
 - `<daml:Class rdf:ID="Animal"/>`
- DAML estende RDF
- Altri esempi

```
<daml:Class rdf:ID="Male">  
  <rdfs:subClassOf  
    rdf:resource="#Animal"/>  
</daml:Class>
```

Disjointness constraints

```
<daml:Class rdf:ID="Female">  
  <rdfs:subClassOf  
    rdf:resource="#Animal"/>  
  <daml:disjointWith  
    rdf:resource="#Male"/>  
</daml:Class>
```

- big e small si potevano definire in modo simile

Attributi

- Relazioni binarie (oggetto, valore-attributo)

```
<daml:ObjectProperty df:ID="hasParent">  
<rdfs:domain rdf:resource="#Animal"/>  
<rdfs:range rdf:resource="#Animal"/>  
</daml:ObjectProperty>
```

Specializzazione proprietà

- Vincoli di inclusione tra relazioni binarie

```
<daml:ObjectProperty df:ID="hasFather">  
  <rdfs:subPropertyOf  
    rdf:resource="#hasParent" />  
  
  <rdfs:range rdf:resource="#Male" />  
  
</daml:ObjectProperty>
```

Restrizioni su cardinalità

- I genitori sono 2

```
<daml:Class rdf:about="#Animal">
  <rdfs:subClassOf>
    <daml:Restriction
      daml:cardinality="2">
        <daml:onProperty
          rdf:resource="#hasParent"/>
        </daml:Restriction>
      </rdfs:subClassOf>
    </daml:Class>
```

Vincoli deboli

- Min-Max cardinality (modo per definire UniqueProperty)

```
<daml:Class rdf:about="#Person">
  <rdfs:subClassOf>
    <daml:Restriction
      daml:maxCardinality="1">
        <daml:onProperty
          rdf:resource="#hasSpouse"/>
        </daml:Restriction>
      </rdfs:subClassOf>
    </daml:Class>
```

Proprietà inverse

```
<daml:ObjectProperty rdf:ID="hasChild">  
  <daml:inverseOf  
    rdf:resource="#hasParent"/>  
</daml:ObjectProperty>
```

- e via scorrendo...

Inference engines

- Per verificare:
 - consistenza ontologie
 - sussunzione (inclusione) tra concetti (per query e classificazione automatica)
 - appartenenza a concetti/relazioni, soddisfacimento proprietà

Inference engines

- LOOM
- Classic
- FaCT
- ...

Ulteriori informazioni

- <http://xml.coverpages.org/daml.html>
- <http://www.daml.org>
- <http://www.ontoknowledge.org/oil/>

Non di soli dati...

- Individuazione automatica di *servizi*
- Basata su semantica (*funzionalità* del servizio)
- Per il formato con cui scambiare dati col servizio esiste standard XML: **WSDL** - Web Service Description Language
 - IBM, Microsoft
 - in evoluzione